

Introducción

Marco

Proyecto de investigación del Laboratorio **SI6** de CITEFA

- Identificación y clasificación de intrusos informáticos basadas en su comportamiento (PICTO 2004)

Objetivo de este trabajo

- Detección de intrusos en el *historial de comandos* UNIX
- Aplicación de la *técnica* desarrollada por M. Li et al. sobre los *datos* recolectados por M. Schonlau et al.
- Comparación de los resultados



Detección de intrusos

Clasificación de técnicas

- Misuse detection
- **Anomaly detection**



Detección de intrusos

Clasificación de técnicas

- Misuse detection
- **Anomaly detection**

Definición


Un **masquerader** o *impostor* es un intruso que intenta tomar la identidad de un usuario legítimo de un sistema informático.

Trabajo previo

Schonlau et al, “*Computer Intrusion: Detecting Masquerades*”, 2001



Datos [Schonlau et al.]¹



Observaciones

- Fuente: acct (UNIX) (*comandos sin argumentos*)
- 50 usuarios “legítimos” + 20 “masqueraders”
- Bloques de 100 comandos
- *Testing*: un bloque es masquerader con probabilidad 1 %, y en este caso el siguiente lo es con 80 %
- Aprox. 5 % de los bloques son masqueraders
- No todos los usuarios contienen masqueraders

User 1

```

cpp
sh
xrdb
cpp
sh
xrdb
mkpts
env
csh
csh
csh
sh
kill
userenv
wait4wm
...

```

¹<http://www.schonlau.net>

Experimentos

Metodología [Schonlau et al.]

- Se calcula un **puntaje** para cada bloque de *testing*.
- Si el puntaje supera cierto **umbral**, se considera **masquerader**.

Técnicas [Schonlau et al.]

- *Uniqueness*
- *Bayes one-step Markov*
- *Hybrid multistep Markov*
- *Sequence-Match*
- *IPAM*
- **Compression** (basado en compress de UNIX)



Compression Method [Schonlau et al.]

Puntaje [Schonlau et al.]

El **puntaje** x de **Compression** se define como el número adicional de bytes necesarios para comprimir un bloque de *testing* concatenado con los datos de *training*:

$$x = \text{compress}(D_{Tr}D_{Te}) - \text{compress}(D_{Tr})$$

donde D_{Tr} es training data, D_{Te} testing data, $D_{Tr}D_{Te}$ es la concatenación de ambos y $\text{compress}()$ es una función que devuelve el número de bytes de los datos comprimidos.



Compression Method [Schonlau et al.]

Puntaje [Schonlau et al.]

El **puntaje** x de **Compression** se define como el número adicional de bytes necesarios para comprimir un bloque de *testing* concatenado con los datos de *training*:

$$x = \text{compress}(D_{Tr}D_{Te}) - \text{compress}(D_{Tr})$$

donde D_{Tr} es training data, D_{Te} testing data, $D_{Tr}D_{Te}$ es la concatenación de ambos y $\text{compress}()$ es una función que devuelve el número de bytes de los datos comprimidos.

Umbral [Schonlau et al.]

Se calcula un **umbral** por usuario basado en los datos del usuario más un desplazamiento basado en los datos de todos los usuarios.



Normalized Compression Distance

Diseño

- Se reprodujo el experimento basado en *compress*, utilizando *NCD* en su lugar.
- Se intentó reproducir lo más exactamente posible el diseño de los experimentos de Schonlau et al.

Concepto

- Medida de *distancia normalizada, genérica y cuasi-universal*
- Basada en noción de *Kolmogorov Complexity* (no computable)
- Aproximación basada en compresores estándares

Trabajos previos

- M. Li et al, "*The Similarity Metric*", 2004
- R. Cilibrasi et al, "*Clustering by Compression*", 2005



Kolmogorov Complexity

Más formalmente...

Definición

La **complejidad de Kolmogorov** de un objeto es la longitud de su descripción más corta en un lenguaje predefinido:

$$K(x) = \min |P| : U(P) = x$$

donde P es un programa que “genera” x sin parámetros y termina, y U es una Máquina Universal de Turing.



Kolmogorov Complexity

Más formalmente...

Definición

La **complejidad de Kolmogorov** de un objeto es la longitud de su descripción más corta en un lenguaje predefinido:

$$K(x) = \min |P| : U(P) = x$$

donde P es un programa que “genera” x sin parámetros y termina, y U es una Máquina Universal de Turing.

Teorema

$K()$ es **no computable**.



Kolmogorov Complexity

Más formalmente...

Definición

La **complejidad de Kolmogorov** de un objeto es la longitud de su descripción más corta en un lenguaje predefinido:

$$K(x) = \min |P| : U(P) = x$$

donde P es un programa que “genera” x sin parámetros y termina, y U es una Máquina Universal de Turing.

Teorema

$K()$ es **no computable**.

$K(x)$ se puede aproximar “desde arriba” mediante un compresor C :

$$|K(x)| < |C(x)| < |x|$$



Compresores

Definición [Li et al.]

Un **compresor** es una función $c : \Omega \rightarrow (0, 1)^*$

- Por conveniencia, definimos C como: $C(x) = |c(x)|$.
- Sólo se consideran compresores tales que $C(x) \leq |x| + O(\log |x|)$



Compresores

Definición [Li et al.]

Un **compresor** es una función $c : \Omega \rightarrow (0, 1)^*$

- Por conveniencia, definimos C como: $C(x) = |c(x)|$.
- Sólo se consideran compresores tales que $C(x) \leq |x| + O(\log |x|)$

Definición [Li et al.]

C es un **compresor normal** si satisface, hasta un término aditivo $O(\log |x|)$:

- $C(xx) = C(x)$ y $C(\lambda) = 0$ donde λ es la cadena vacía (*idempotencia*)
- $C(x) \leq C(xy)$ (*monotonicidad*)
- $C(xy) = C(yx)$ (*simetría*)
- $C(xy) + C(z) \leq C(xz) + C(yz)$ (*distributividad*)



Normalized Compression Distance

Definición [Li et al.]

La **Normalized Compression Distance** entre dos cadenas x e y se define como:

$$NCD(x, y) = \frac{C(xy) - \min(C(x), C(y))}{\max(C(x), C(y))} \leq 1 + \epsilon$$



Normalized Compression Distance

Definición [Li et al.]

La **Normalized Compression Distance** entre dos cadenas x e y se define como:

$$NCD(x, y) = \frac{C(xy) - \min(C(x), C(y))}{\max(C(x), C(y))} \leq 1 + \epsilon$$

Observación

- $NCD(x, y) \rightarrow 0$ cuando la similitud entre x e y es máxima.
- $NCD(x, y) \rightarrow 1$ cuando la similitud entre x e y es mínima.



Normalized Compression Distance

Definición [Li et al.]

La **Normalized Compression Distance** entre dos cadenas x e y se define como:

$$NCD(x, y) = \frac{C(xy) - \min(C(x), C(y))}{\max(C(x), C(y))} \leq 1 + \epsilon$$

Observación

- $NCD(x, y) \rightarrow 0$ cuando la similitud entre x e y es máxima.
- $NCD(x, y) \rightarrow 1$ cuando la similitud entre x e y es mínima.

Teorema [Cilibrasi et al, 2005]

Si C es *normal*, entonces $NCD(x, y)$ es una **similarity metric**, y es **cuasi-universal**.

Implementación

Puntaje NCD

El **puntaje** de un bloque de testing se calcula como:

$$x_{NCD} = \frac{C(D_{Tr}D_{Te}) - C(D_{Te})}{C(D_{Tr})} \leq 1 + \epsilon$$

donde D_{Tr} es training data, D_{Te} testing data, $D_{Tr}D_{Te}$ es la concatenación de ambos y $C()$ es un compresor normal.



Implementación

Puntaje NCD

El **puntaje** de un bloque de testing se calcula como:

$$x_{NCD} = \frac{C(D_{Tr}D_{Te}) - C(D_{Te})}{C(D_{Tr})} \leq 1 + \epsilon$$

donde D_{Tr} es training data, D_{Te} testing data, $D_{Tr}D_{Te}$ es la concatenación de ambos y $C()$ es un compresor normal.

Umbral NCD

Se calcula un **umbral** por usuario basado en los datos del usuario más un desplazamiento basado en los datos de todos los usuarios.



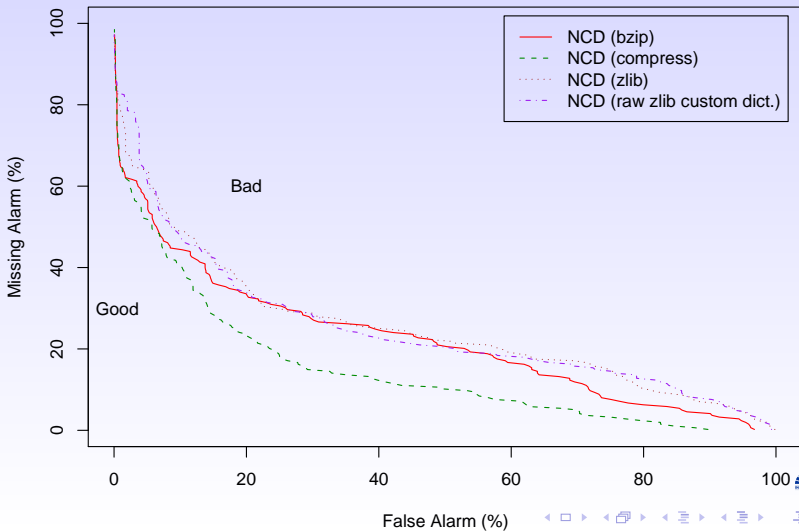
Resultados: comparación

<i>Método</i>	<i>False Alarm Rate (%)</i>	<i>Missing Alarm Rate (%)</i>
Uniqueness	1.4	60.6
Bayes one-step Markov	6.7	30.7
Hybrid multistep Markov	3.2	50.7
Compression	5.0	65.8
Sequence-Match	3.7	63.2
IPAM	2.7	58.9
NCD (<i>bzip</i>)	0.6	69.6
NCD (<i>compress</i>)	2.9	57.5
NCD (<i>zlib</i>)	1.2	77.9
NCD (<i>raw zlib cust. dict.</i>)	1.3	82.6


Cuadro: Comparación de todos los métodos (apuntando a FAR de 1%)




Curvas ROC (NCD)



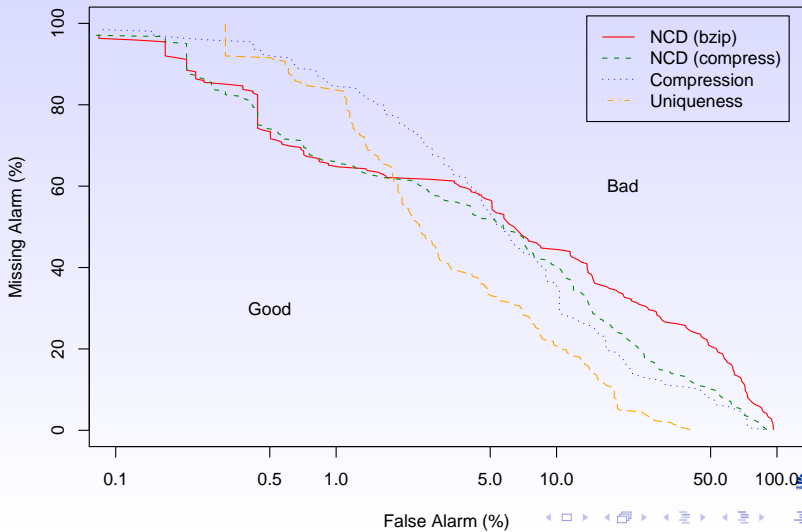
Curvas ROC (NCD)



Curvas ROC (Comparación)



Curvas ROC (Comparación)



Outline

- 1 Introducción y antecedentes
 - Objetivos
 - Detección de intrusos
 - Datos utilizados
 - Técnica utilizada
- 2 Teoría
 - Kolmogorov Complexity
 - Compresores
 - Normalized Compression Distance
- 3 Experimentos
 - Herramientas
 - Resultados
- 4 Conclusiones y tareas pendientes



Conclusiones y tareas pendientes

Conclusiones

- La técnica basada en *NCD*:
 - produjo resultados similares a los obtenidos por otras técnicas
 - produjo mejores resultados para *FAR* bajos
 - se acercó más a los valores de *FAR* deseados que otras técnicas
- El compresor `raw zlib` con diccionario no resultó en mejoras significativas

Tareas pendientes

- Elección de un compresor óptimo para los datos
- Manejar bloques de datos de tamaño menor o variable
- Actualización de los “perfiles” de los usuarios
- Utilización de datos más completos



¿Preguntas?



Muchas Gracias

Maximiliano Bertacchini

mbertacchini@citefa.gov.ar

POWERED BY BEAMER + L^AT_EX



ITBA
INSTITUTO TECNOLÓGICO DE BUENOS AIRES
UNIVERSIDAD DEL SAHARA

Distancias y métricas

Definición

D es una **función de distancia** en un conjunto Ω : $D : \Omega \times \Omega \rightarrow \mathbb{R}^+$.

Definición

D es una **métrica** si satisface para todo $x, y, z \in \Omega$:

- $D(x, y) = 0$ iff $x = y$ (*identidad*)
- $D(x, y) = D(y, x)$ (*simetría*)
- $D(x, y) \leq D(x, z) + D(z, y)$ (*desigualdad triangular*)

Definición

D es una **métrica admisible** si es una métrica *computable* y *densa*.



Distancias y métricas

Definición

D es una **función de distancia** en un conjunto Ω : $D : \Omega \times \Omega \rightarrow \mathbb{R}^+$.

Definición

D es una **métrica** si satisface para todo $x, y, z \in \Omega$:

- $D(x, y) = 0$ iff $x = y$ (*identidad*)
- $D(x, y) = D(y, x)$ (*simetría*)
- $D(x, y) \leq D(x, z) + D(z, y)$ (*desigualdad triangular*)

Definición

D es una **métrica admisible** si es una métrica *computable* y *densa*.

Ejemplo

$D(x, y) = |x - y|$ donde $x, y \in \mathbb{R}^n$ (*distancia euclídea*)

